arXiv:2304.01696v1 [eess.SP] 4 Apr 2023

基于经验模态分解的超可靠低时延通信预测性资源分配

Chandu Jayawardhana、Thushan Sivalingam、Nurul Huda Mahmood、Nandana Rajatheva 和 Matti Latva-Aho；6G旗舰项目，无线通信中心，奥卢大学，奥卢，芬兰；{chandu.wijenayakejayawardhana, thushan.sivalingam, nurulhuda.mahmood, nandana.rajatheva, matti.latva-aho}@oulu.fi

摘要——**有效的资源分配是实现超可靠低时延通信（URLLC）服务严格性能目标的关键要求。预测未来干扰并据此设计高效的干扰管理算法，是有效为超可靠低时延通信服务分配资源的一种方式。本文提出一种基于经验模态分解（EMD）的混合预测方法，用于预测干扰，并根据预测结果为下行链路分配资源。经验模态分解用于分解用户设备所面临的历史干扰值。采用长短期记忆方法和自回归积分滑动平均方法预测各分解分量。根据各分解分量的预测值重构最终干扰预测值。研究发现，这种基于分解的预测方法可将预测的均方根误差降低** $20-25\%$**。研究还发现，采用基于经验模态分解的干扰预测的资源分配算法能够实现接近最优的资源分配；与基于先进基线预测算法的资源分配相比，其对应的中断概率低** $2-3$ **个数量级。**

关键词—**自回归滑动平均、基于分解的预测、经验模态分解、本征模态函数、长短期记忆、残差、超可靠低时延通信。**

I. 引言

第五代（5G）新空口引入了超可靠低时延通信（URLLC）业务类别，以支持任务关键型应用；在这些应用中，不间断且稳健的数据交换至关重要。其应用场景包括工厂自动化、流程工业、智能电网、智能交通系统和专业音频应用 [1]。URLLC 服务的目标时延和可靠性分别为 1 毫秒和 $1-10^{-5}$ [2]。

URLLC 面临三项显著的底层挑战：不确定的业务到达、包括衰落在内的随机信道损伤，以及随机干扰 [3]。传统资源分配方法通过采用基于观测结果的传输策略来应对这些挑战，例如在传输失败时进行混合自动重传请求（HARQ）重传 [4]。由于 URLLC 服务的时延和可靠性要求严格得多，这类传统方案无法高效地支持此类服务 [5]。

本研究由芬兰科学院 6Genesis旗舰项目资助（资助编号：346208）。

现有的 5G 超可靠低时延通信使能技术分别侧重于实现低时延和高可靠性。尽管这些独立开发的可靠性与时延使能技术符合 5G 标准，但它们可能不足以满足超越 5G 的网络需求。例如，5G 通过过度配置资源来达到可靠性要求，而这些资源原本可以分配给其他服务，例如增强型移动宽带（eMBB）或海量机器类通信（mMTC）。因此，必须采用创新的智能解决方案，在高效利用稀缺资源的同时，兼顾时延和可靠性。

开发一种能够预测未来干扰值并主动分配资源的智能机制，被视为可促进高效资源分配的超可靠低时延通信潜在赋能技术 [6]。链路自适应是一种传统方法，它根据过去的干扰样本预测未来的干扰值 [7]。然而，传统链路自适应方案的一个缺点是，它们只考虑过去所有干扰值的均值，而忽略了干扰的突发波动。这种做法可能导致预测不准确，因为它缺乏对完整干扰分布的了解。因此，利用过去完整干扰分布进行预测的干扰预测方案将能带来更准确的预测。

文献 [8], 提出了一种递归预测器，将干扰的自相关转换为自回归移动平均表示，并利用该表示估计未来的干扰。文献 [9]提出了面向图形处理器系统的预测式干扰感知资源分配方法，以提高深度学习模型的训练效率。此外，文献 [10], 提出了用于车联网通信的干扰预测方法，通过预测车辆间的干扰来避免数据包碰撞。由于干扰是一种高度随机的信号，且受到多个干扰源的影响，准确预测干扰是一项复杂的工作。因此，有必要探索更准确的预测机制。为此，我们提出一种基于经验模态分解（EMD）的新方法。

基于预测干扰值的超可靠低时延通信服务高效资源分配研究仍处于早期阶段 [11]。因此，我们提出了一种采用经验模态分解的全新混合资源分配方案 [12]。在所提出的方法中，我们使用经验模态分解对原始信号进行分解，并使用长短期

记忆网络（LSTM） [13] 和自回归移动平均模型（ARIMA） [14]预测分解后的信号分量。然后，将各个分量的预测值相加，得到总干扰预测值。最后，根据预测的干扰值，在下行链路中高效分配资源。该方案实现了近乎最优的性能，而采用传统的干扰预测和资源分配方法很难达到这一水平。

本文其余部分安排如下。第二节介绍系统模型和问题陈述。第三节提出基于EMD的预测与资源分配方案。第四节给出仿真结果和性能分析。最后，第五节给出结论。

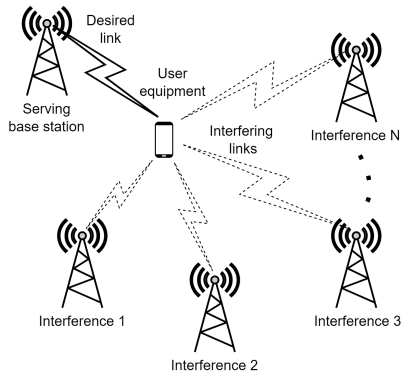


图 1. 系统模型：期望链路与 N 个干扰源同时工作。

II. 系统模型

考虑一个无线网络的下行链路。如图1所示，我们关注在存在 N 个干扰源时运行的一个URLLC用户的性能。假设期望信道的平均信噪比（SNR）为 $\bar{\gamma}$，而干扰链路的平均信噪比（称为干扰噪声比（INR））在给定范围 $[\gamma_{min}, \gamma_{max}]$内均匀分布。假设期望链路与信噪比最高的基站建立连接。因此，假设信噪比最高的干扰链路（其信噪比值为γ_{max}）低于期望链路（其信噪比为$\bar{\gamma} > \gamma_{max}$）。此外，假设发射机之间不存在协作。我们还考虑单天线（单输入单输出（SISO））瑞利块衰落模型。服务基站通过给定的目标错误概率ε，经由期望下行链路发送 D 比特。目标是通过预测未来的干扰值，尽可能高效地分配信道使用次数 R ，从而同时保证低时延和高可靠性。

超可靠低时延通信传输通常在较短的传输时间间隔（TTI）内进行，该间隔可短至 0.1 ms [15]。由于典型无线传输的相干时间远长于此时长，因此信道相干时间可跨越多个 TTI。假设发射机在该相干时间内能够获取足够的期望信道状态信息（CSI）。此外，我们认为，用户设备（UE）会将其过去观测到的总干扰值更新给服务基站。这样，服务基站便能获得更多关于接收机处干扰的信息，从而能够在下行链路中执行所提出的干扰预测方案。

III. 干扰预测与资源分配

在这项工作中，我们提出使用经验模态分解（EMD）分解复合总干扰信号，并分别预测各个分量，以提高预测准确度。图 2 展示了所提方法与先进方法的示意图。

A. 经验模态分解

EMD 使用启发式分解方法 [12] 将过去的总干扰信号功率分解为本征模态函数（IMF）。通过这种分解方法，我们可以得到按频率排序的本征模态函数分量。最初的本征模态函数包含高频振荡。随后，随着本征模态函数序号增加，振荡频率逐渐降低，最终得到更具线性的本征模态函数。总干扰信号功率可使用分解后的分量重构如下：

$$f(t) = \sum_{i=1}^{L-1} IMF_i(t) + res(t), \tag{1}$$

其中， L 为分解分量的数量， res（t）为残差。此处， L 并非预先确定，而仅取决于信号的性质。在开发和训练模型时，预测高振荡信号比预测振荡较弱的信号更具挑战性。因此，我们没有采用单一模型来预测整体干扰，而是针对每个本征模态函数和残差分量分别设计了模型。随着本征模态函数编号增加，每个模型的输入信号振荡性会减弱。因此，模型的预测准确度得以提高，模型训练任务也变得更易处理。与式（1）类似，总干扰的预测值也可以通过汇总各本征模态函数和残差的单独预测值进行重构。

将总干扰信号分为两组，以获得训练样本和验证样本。可以使用预先设定的训练样本百分比值（例如，80%）进行划分。总干扰信号中的样本数记为 T。训练数据和验证数据中的样本数分别记为 P 和 M，其中$T = P + M$。

B. 预测模型选择与训练

采用两种时间序列预测方法来预测每个分解分量的值，分别是长短期记忆网络 [14]和自回归积分滑动平均模型 [13]。选择 ARIMA 模型是因为它能够处理非平稳数据 [13]。ARIMA 的流程包括四个步骤：识别、估计、诊断和预测。长短期记忆网络循环神经网络

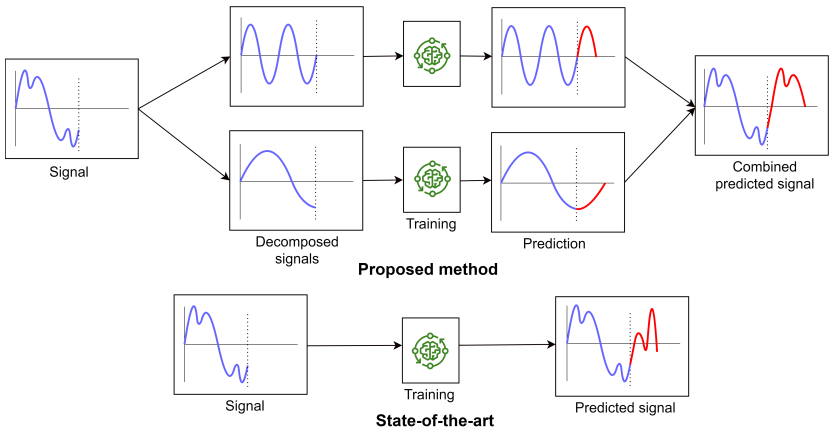


图 2. 所提出的资源分配方案与最先进的资源分配方案对比。

（RNN）方法之所以被选用，是因为它能够学习长期依赖关系，并长期保留已学习的信息，从而支持未来决策 [14]，同时克服传统循环神经网络的缺点，例如梯度消失或梯度爆炸。

将每个本征模态函数和残差分别输入这两种预测算法。此处，针对每个本征模态函数和残差分别训练模型，使用 P 个训练样本，以优化各分量信号的预测准确度。采用长短期记忆网络方法训练的模型总数等于本征模态函数和残差的数量之和（L），与自回归积分滑动平均模型相同。这两种预测方法基于训练好的神经网络和时间序列预测技术来预测下一个样本值。

由于有 M 个验证数据点，因此重复 M 次单步预测方法，以获得预测值集合。与一次性预测所有 M 个未来值相比，每次迭代只预测一个未来值的优势在于，我们可以通过比较最新预测值与实际值，在每一步优化模型。通过始终将最新数据点纳入模型训练，可以提高预测准确度。随后，将各模型预测的本征模态函数值和残差值相加，使用两种方法获得最终预测的干扰信号，具体如下

$$LSTM_{recon} = \sum_{t=1}^{M}(\sum_{i=1}^{L-1} IMF_{LSTM(i)}(t) + res_{LSTM}(t)), \tag{2}$$

$$ARIMA_{recon} = \sum_{t=1}^{M}(\sum_{i=1}^{L-1} IMF_{ARIMA(i)}(t) + res_{ARIMA}(t)), \tag{3}$$

其中，$LSTM_{recon}$ 是使用长短期记忆网络方法，根据各本征模态函数和残差的预测值重构得到的信号，$ARIMA_{recon}$ 是使用自回归积分滑动平均模型方法，根据各本征模态函数和残差的预测值重构得到的信号。$IMF_{LSTM\ (i)}(t)$ 是使用经过训练、用于预测时间步 t 处本征模态函数 (i) 的长短期记忆网络模型得到的预测值，$IMF_{ARIMA\ (i)}(t)$ 是使用经过训练、用于预测时间步 t 处本征模态函数(i) 的自回归积分滑动平均模型得到的预测值。这里，$res_{LSTM}(t)$、$res_{ARIMA}(t)$ 分别是时间步 t 处长短期记忆网络模型和自回归积分滑动平均模型的残差值。

除分解后的信号外，还将总干扰的训练样本输入长短期记忆网络和自回归积分滑动平均模型，以进行基线比较。相应的预测结果为

$$LSTM_{Signal} = \sum_{t=1}^{M} Signal_{LSTM}(t), \tag{4}$$

$$ARIMA_{Signal} = \sum_{t=1}^{M} Signal_{ARIMA}(t), \tag{5}$$

其中，$LSTM_{Signal}$ 是不使用经验模态分解时通过长短期记忆网络方法预测的信号，$ARIMA_{Signal}$ 是不使用经验模态分解时通过自回归积分滑动平均模型方法预测的信号，$Signal_{LSTM}(t)$ 是使用长短期记忆网络方法在时间步 t 的预测值，$Signal_{ARIMA}(t)$ 是使用自回归积分滑动平均模型方法在时间步 t 的预测值。

C. 资源分配

假设已通过信道状态信息估计获知期望信号 S 的功率，则预测的信干噪比（SINR）$\hat{\gamma}$ 可计算为

$$\hat{\gamma} = \frac{S}{\hat{I} + N_0}, \tag{6}$$

其中，$\hat{I}$ 是预测的干扰功率，N_0 是归一化噪声功率。根据有限块长理论，[16]，在加性高斯白噪声（AWGN）信道中使用 R次信道使用次数、在给定译码错误概率 ε 下可传输的信息比特数 D 可计算为

$$D = RC(\hat{\gamma}) - Q^{-1}(\varepsilon)\sqrt{RV(\hat{\gamma})} + O(\log_2 R), \tag{7}$$

其中，$C(\hat{\gamma}) = \log_2(1+\hat{\gamma})$ 是有限码长制度下加性高斯白噪声信道的香农容量，$V(\hat{\gamma}) = \left(1 - \frac{1}{(1+\hat{\gamma})^2}\right)(\log_2 e)^2$ 是以每个信道的平方信息单位衡量的信道色散

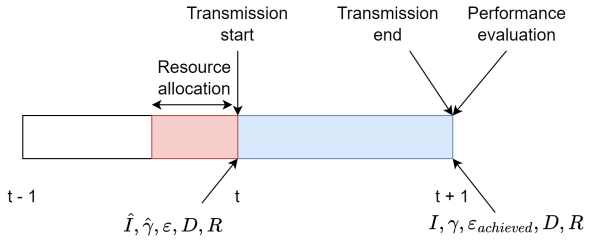


图 3. 资源分配与性能评估时间线。

而 Q^{-1} 是 Q 函数 [3]的反函数。利用上述信息，传输 D 比特且目标错误概率为 ε 时所需的资源数（信道利用率）R 可估算为 [4]

$$R \approx \frac{D}{C(\hat{\gamma})} + \frac{Q^{-1}(\varepsilon)^2 V(\hat{\gamma})}{2C(\hat{\gamma})^2}\left[1 + \sqrt{1 + \frac{4DC(\hat{\gamma})}{Q^{-1}(\varepsilon)^2 V(\hat{\gamma})}}\right]. \tag{8}$$

如图 3 所示，该资源分配在实际传输（$t-1$）之前的一个时间步内完成。在时间 t 使用已分配的 R 个资源传输 D 比特后，我们可以获得 D 比特所经历的确切总干扰 I 。因此，可以得到实际信干噪比 γ ，如式 (9) 所示。需要注意的是，现在将使用实际总干扰 I 值计算 γ ，即

$$\gamma = \frac{S}{I + N_0}. \tag{9}$$

由于我们最初是基于目标错误概率 ε 分配资源 R ，现在可以通过重新整理式 (7) 中的项，并将预测信干噪比值 $\hat{\gamma}$ 替换为实际信干噪比值 γ ，得到实际错误概率，如下所示

$$\varepsilon_{achieved} \approx Q\left(\frac{RC(\gamma) - D}{\sqrt{RV(\gamma)}}\right). \tag{10}$$

最后，我们可以比较目标错误概率与实际错误概率。上述过程可以针对不同的目标错误率值进行迭代，从而获得实际错误率值随目标错误率值变化的情况。

IV. 仿真结果

除非另有说明，仿真参数列于表 I 中。可根据需求调整仿真参数，而不会影响模型的性能。

A. 基于经验模态分解的预测准确度分析

我们对所有模型采用相同的超参数设置，以验证基于经验模态分解的预测准确度，并将其与不使用经验模态分解的传统预测方法进行比较。

表 I 仿真参数

描述	值
干扰源数量（N）	5
干扰源的信噪比值	[5, 3, 0, -2, -5] 分贝
期望信号的信干噪比值（$\bar{\gamma}$）	20 分贝
考虑的样本数	100
信道模型	瑞利块衰落单输入单输出
比特数（D）	50
目标误码率（ε）	$10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}$
IRR 的遗忘因子（α）	0.01

尽管预测模型分别根据本征模态函数、残差和总信号的训练数据集进行训练，但所有这些模型所使用的超参数仍保持不变。所有模型均使用表 II 中的以下超参数进行训练。

表 II 所有模型训练所用的超参数

方法	超参数	值
长短期记忆网络/自回归积分滑动平均模型	训练窗口	30
	训练轮数	100
	激活函数	ReLU
	优化器函数	Adam
LSTM	损失函数	MSE
	LSTM 第 1 层神经元数量	100
	LSTM 第 2 层神经元数量	100
	全连接层神经元数量	1
	自回归的前序样本数（p）	30
自回归积分滑动平均模型	移动平均的前序样本数（q）	0
	差分阶数（d）	1

将各个预测元素相加，生成基于经验模态分解的预测输出。我们将基于EMD的预测方法与传统预测方法（不使用EMD）进行比较。采用均方根误差（RMSE）作为评估指标来比较性能。对于每种方法，通过比较重构信号与总干扰信号的验证数据集，得到一个RMSE值。随后，再通过比较干扰信号的预测值与总干扰信号的验证数据集，得到一个RMSE值。所得RMSE值列于表 III，预测信号如图 4 和图 5 所示。

表 III 预测信号与原始信号的均方根误差比较

比较标准	自回归积分滑动平均模型	LSTM
原始数据与预测数据（未使用经验模态分解）	2.13	2.49
原始数据与重构数据（使用经验模态分解）	1.63	1.91

如表 III 所示，使用长短期记忆网络和自回归积分滑动平均模型得到的重构信号的均方根误差均小于预测信号的均方根误差。因此，这表明基于经验模态分解的预测方法优于传统预测方法。

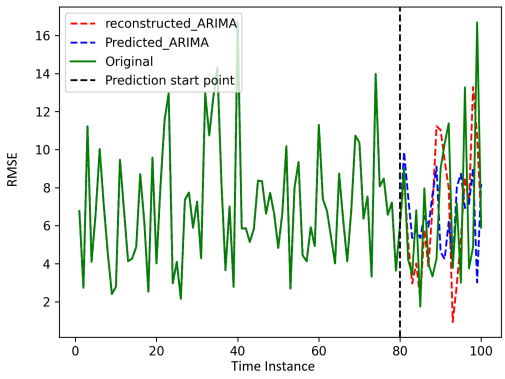


图 4. ARIMA 方法的均方根误差比较。

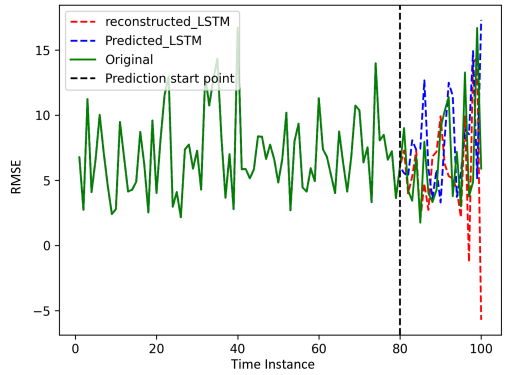


图 5. 长短期记忆网络方法的均方根误差比较。

B. 资源分配的基线方案

我们将所提方案与基线方案进行比较，以评估其性能。因此，采用了以下两种基线方案 [16]。

1) 基于移动平均的估计：这是一种传统的基于加权平均的估计过程。该过程经过调整，用于预测干扰信号功率，作为第一种基线方案。在此，时刻 t测得的干扰信号通过一阶低通无限冲激响应 (IIR) 滤波器。干扰估计值为

$$\hat{I}_{t+1} = \alpha I_{t-1} + (1-\alpha)\hat{I}_t, \tag{11}$$

其中，α $(0 < \alpha < 1)$ 是滤波器的遗忘因子 (FF)。它决定了与之前的测量值相比，赋予最新测量值的权重。基于仿真启发式分析，已确定 $\alpha = 0.01$ 对时延性能而言是最优的 [7]。

2) 理想先知辅助估计：理想信息辅助估计器被视为最优估计器。在这一干扰预测场景中，假设发射机能够准确获知发射信号将遇到的干扰状况。换言之，$I = I$。

为进行比较，我们评估所提出方案与基线方案的性能，其中使用基线方案预测的干扰值为 I_{IIR} 和

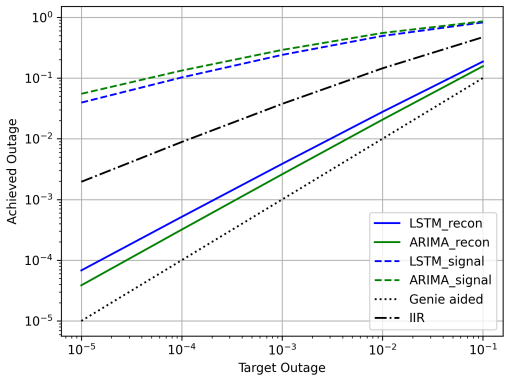


图6. 不同预测方法下实际中断与目标中断的对比。

$\hat{I}_{Genie}$。随后，使用上述流程，针对同一组目标中断值获取实际中断结果。最后，通过将所提出方案的结果与基线方案的结果进行比较，得出结论。

C. 总体资源分配与性能分析

我们在第四节A中对所有模型使用相同的超参数，仅用于比较基于经验模态分解（EMD）的预测与传统预测方法的预测准确度。由于随着本征模态函数数量增加，各模型输入信号的特性会发生变化，因此可以通过针对每个模型单独调整超参数来获得较高的预测准确度。假设我们对每个模型使用相同的超参数。在这种情况下，输入信号更具线性的模型会出现过拟合，而输入信号更随机的模型则会出现欠拟合。此外，对较高阶本征模态函数使用较宽松的超参数，可以大幅缩短模型训练时间。例如，对较高阶本征模态函数使用较小的训练窗口，可以减少训练时间，同时仍能获得高准确度的预测。

根据预测的干扰 I为下行信道分配资源。通过模拟不同的目标错误率值 ε，获得了达到的块错误率目标 $\varepsilon_{achieved}$。我们将基于EMD的资源分配与两种基线方案进行比较。由于理想信息辅助估计器假定其已知实际信干噪比，因此能够分配恰好满足目标中断所需数量的资源，如图6所示。理想信息辅助估计器生成的曲线被视为资源的最优分配。任何与理想信息辅助估计器曲线偏差较小的曲线，都可视为资源的高效分配。相反，曲线偏离理想信息辅助估计器曲线越远，效率越低。

如图6所示，基于IIR滤波器的估计性能较差，只能达到约10%的块错误率（BLER）目标。基于IIR滤波器得到的中断曲线与预期的理想信道辅助中断曲线存在明显偏差。

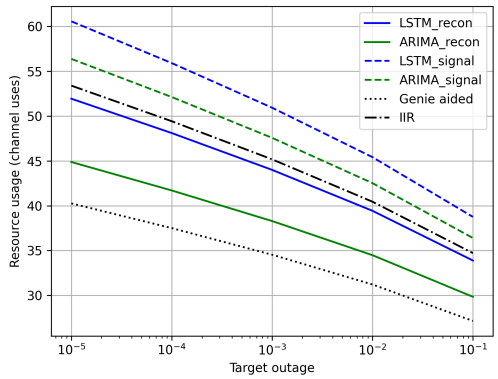


图7. 不同预测方法下资源使用量与目标中断率的关系。

基于IIR滤波器的估计所达到的块错误率目标，可能仅对增强型移动宽带服务 [17]而言具有较高的资源效率。对于超可靠低时延通信服务，预计需要达到更严格的中断目标。

可以观察到，仅使用LSTM和ARIMA方法而不采用EMD的资源分配，与理想信息辅助资源分配相比性能较差，但优于基于IIR的资源分配。相比之下，采用基于EMD的预测方法所达到的中断率优于基于IIR滤波器的方法以及不使用EMD的方法。如 $ARIMArecon$曲线所示，采用EMD和ARIMA进行干扰预测的资源分配方法，以近乎最优的方式分配资源，几乎满足了目标错误率。其次，采用基于EMD的LSTM方法实现了第二优的资源分配，如 $LSTMrecon$曲线所示。这也证明，基于EMD的预测方法比分非EMD预测方法能够更高效地分配资源。上述中断率目标对应的资源使用量如图7所示。理想信息辅助估计器分配的资源数量最少且达到最优，因为假设其拥有关于干扰的精确先验知识。我们提出的基于EMD的预测方案能够实现接近最优的性能，分配的资源少于最先进的干扰预测方案。

V. 结论

本文研究了面向超可靠低时延通信服务的预测资源分配。我们考虑了存在 N 干扰链路时的目标下行链路。我们采用经验模态分解算法，将总干扰信号功率分解为本征模态函数和残差。这种分解使我们能够精确预测未来的干扰值。除经验模态分解外，我们还使用两种预测算法来训练模型：长短期记忆网络和自回归积分滑动平均模型。为实现高效资源分配这一最终目标，我们还评估了基于经验模态分解的混合预测方案的性能。根据预测的干扰值，分配下行链路资源以抵御实际干扰的影响。最后，我们将所提出方案的性能与两种基线方案进行了比较，结果表明该方案能够达到近乎最优的性能。

参考文献

[1] P. Schulz、M. Matthe、H. Klessig、M. Simsek、G. Fettweis、J. Ansari、S. A. Ashraf、B. Almeroth、J. Voigt、I. Riedel、A. Puschmann、A. Mitschele-Thiel、M. Muller、T. Elste 和 M. Windisch，《5G中的时延关键物联网应用：无线接口与网络架构设计展望》，*IEEE*通信杂志，第55卷，第2期，第70–78页，2017年。[2] C. Padilla、R. Hashemi、N. H. Mahmood 和 M. Latva-Aho，《超可靠低时延通信场景中的干扰预测与资源分配非线性自回归神经网络》，载于*2021*年信息与通信技术融合国际会议（*ICTC*），2021年，第184–189页。[3] N. H. Mahmood、O. A. López、H. Alves 和 M. Latva-Aho，《超越5G网络中超可靠低时延通信的预测性干扰管理算法》，*IEEE*通信快报，第25卷，第3期，第995–999页，2021年。[4] A. Anand 和 G. de Veciana，《5G无线网络中超可靠低时延通信流量的资源分配与混合自动重传请求优化》，*IEEE*通信领域精选期刊，第36卷，第2421页，2018年11月，第2411页，第1期。[5] M. Bennis、M. Debbah 和 H. V. Poor，《超可靠低时延无线通信：尾部、风险与规模》，*IEEE*会刊，第106卷，第10期，第1834–1853页，2018年。[6] H. Li、J. Wang、C. Hu、X. Chen、X. Liu、S. Jang 和 G. Dudek，《通过持续知识蒸馏预测通信流量》，载于*ICC 2022 - IEEE*国际通信会议，2022年，第5481–5486页。[7] G. Pocovi、B. Soret、K. I. Pedersen 和 P. Mogensen，《蜂窝网络中超可靠低时延通信的MAC层增强》，载于*2017*年*IEEE*国际通信会议研讨会（*ICC*研讨会），2017年，第1005–1010页。[8] J. F. Schmidt、U. Schilcher、M. K. Atiq 和 C. Bettstetter，《无线网络中的干扰预测：随机几何与递归滤波相结合》，*IEEE*车辆技术汇刊，第70卷，第3期，第2783–2793页，2021年。[9] G. Yeung、D. Borowiec、R. Yang、A. Friday、R. Harper 和 P. Garraghan，《Horus：深度学习系统中的干扰感知与预测式调度》，*IEEE*并行与分布式系统汇刊，第33卷，第1期，第88–100页，2022年。[10] Y. Segawa、S. Tang、T. Ueno、T. Ogishi 和 S. Obana，《通过干扰预测与多区间扩展提升C-V2X侧链路性能》，*IEEE Access*，第10卷，第42 518–42 528页，2022年。[11] M. Li、C. Chen、C. Hua 和 X. Guan，《面向工业无线网络低时延接入的基于学习的预分配方案》，*IEEE*无线通信汇刊，第19卷，第664页，2020年1月，第650页，第1期。[12] A. Zeiler、R. Faltermeier、I. R. Keck、A. M. Tomé、C. G. Puntonet 和 E. W. Lang，《经验模态分解——简介》，载于*2010*年国际联合神经网络会议（*IJCNN*），2010年，第1–8页。[13] B. Zhou、D. He 和 Z. Sun，《使用ARIMA/GARCH模型进行流量建模与预测》，载于新兴电信网络建模与仿真工具，A. Nejat Ince 和 E. Topuz 编。美国马萨诸塞州波士顿：Springer US，2006年，第101–121页。[14] X. H. Le、H. Ho、G. Lee 和 S. Jung，《长短期记忆（LSTM）神经网络在洪水预测中的应用》，*Water*，第11卷，第1387页，2019年7月。[15] J. Sachs、G. Wikstrom、T. Dudda、R. Baldemair 和 K. Kittichokechai，《面向超可靠低时延通信的5G无线网络设计》，*IEEE Network*，第32卷，第2期，第24–31页，2018年。[16] Y. Polyanskiy、H. V. Poor 和 S. Verdu，《有限码长体制下的信道编码速率》，*IEEE*信息论汇刊，第56卷，第5期，第2307–2359页，2010年。[17] M. Agiwal、A. Roy 和 N. Saxena，《下一代5G无线网络：综合综述》，*IEEE*通信调查与教程，第18卷，第3期，第1617–1655页，2016年。